

Iasmin Coelho

**ESTUDO SOBRE A APLICAÇÃO DE REDES NEURAIS  
RECORRENTES PARA PREVISÃO DA GERAÇÃO EÓLICA E  
DO PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS**

Trabalho de Conclusão de Curso  
submetido ao Departamento de  
Engenharia Elétrica da Universidade  
Federal de Santa Catarina para a  
obtenção do título de Bacharel em  
Engenharia Elétrica  
Orientador: Prof. Erlon Cristian  
Finardi, Dr.

Florianópolis  
2018

Ficha de identificação da obra elaborada pelo autor  
através do Programa de Geração Automática da Biblioteca Universitária  
da UFSC.

Coelho, Iasmin

Estudo sobre a aplicação de redes neurais  
recorrentes para previsão da geração eólica e do Preço  
de Liquidação das Diferenças / Iasmin Coelho ;  
orientador, Erlon Cristian Finardi, 2018.

67 p.

Trabalho de Conclusão de Curso (graduação) -  
Universidade Federal de Santa Catarina, Centro  
Tecnológico, Graduação em Engenharia Elétrica,  
Florianópolis, 2018.

Inclui referências.

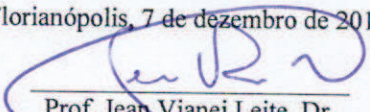
1. Engenharia Elétrica. 2. Rede Neurais  
Recorrentes. 3. Geração de cenários. 4. Geração  
Eólica. 5. Preço de Liquidação das Diferenças. I.  
Finardi, Erlon Cristian. II. Universidade Federal  
de Santa Catarina. Graduação em Engenharia Elétrica.  
III. Título.

Iasmin Coelho

**ESTUDO SOBRE A APLICAÇÃO DE REDES NEURAIS  
RECORRENTES PARA PREVISÃO DA GERAÇÃO EÓLICA E  
DO PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS**

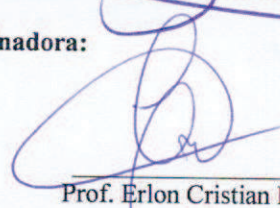
Este Trabalho foi julgado adequado para obtenção do Título de Bacharel  
em Engenharia Elétrica e aprovado em sua forma final pela Banca  
Examinadora

Florianópolis, 7 de dezembro de 2018.

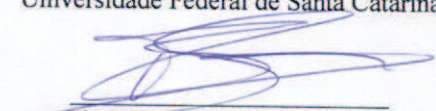


Prof. Jean Viane Leite, Dr.  
Coordenador do Curso


**Banca Examinadora:**



Prof. Erlon Cristian Finardi, Dr.  
Orientador  
Universidade Federal de Santa Catarina



Tiago G. Leite Ferreira, M. Sc.  
Flow Energia



Prof. Kenny Vinente, M. Sc.  
Universidade Federal do Amazonas



Este trabalho é dedicado ao meu avô, o verdadeiro engenheiro da nossa família.



## **AGRADECIMENTOS**

Agradeço a Deus por sempre ter ouvido minhas orações, mostrando através das suas realizações que os pensamentos positivos nos momentos mais desanimadores me levaram até meus objetivos.

A pessoa que escolhi para dividir a vida comigo, Matheus, que passou incontáveis tardes estudando ao meu lado e que me deu a coragem que precisava para continuar nos momentos mais difíceis dessa trajetória. Você me inspira todos os dias a ser melhor.

Aos meus pais e minha avô que me incentivaram a buscar uma formação superior de qualidade e que sempre compreenderam os momentos de isolamento nos fins de semestre.

Ao professor Erlon, por aceitar orientar esse trabalho, mesmo já tendo tantos alunos para orientar. Obrigada pela oportunidade de estudar temas que gosto tanto durante a realização desse trabalho.

A Renata Pedrini, que sempre mostrou total disposição para ajudar e tirar minhas dúvidas ao longo dessa pesquisa.

A Universidade Federal de Santa Catarina, que oferece cursos de excelência e gratuitos, mas além disso nos ensina a ser solidários com as diferenças dos outros. Sempre sentirei orgulho da minha formação, não apenas profissional, mas de como essa universidade me mostrou que podemos acreditar na bondade das pessoas.

E a comissão de formatura que, apesar de não saber, está realizando o meu sonho de participar de um baile de gala.





Se não puder fazer tudo, faça tudo que puder.  
(Paulo Roberto C. Horta)



## RESUMO

Este trabalho descreve um estudo sobre a aplicação de uma rede neural recorrente para gerar cenários de geração eólica e de Preços de Liquidação das Diferenças, os quais são parâmetros relevantes para diversos processos de tomada de decisão no mercado de energia elétrica do Brasil. Dado que as redes neurais têm apresentado resultados muito relevantes em diversos tipos de problemas na literatura, sua aplicação se mostra pertinente para melhorar a geração desses cenários. Para verificar a viabilidade do seu uso, são feitos testes com o objetivo de medir o nível de assertividade das redes neurais quando comparadas com os dados históricos. Nos resultados, observou-se a capacidade de aprendizado da rede neural recorrente e sua facilidade em prever parâmetros que possuem padrões estatísticos. Entretanto, conclui-se que a rede apresenta resultados mais significativos para geração de uma única previsão, podendo gerar melhores resultados em modelos determinísticos. Por outro lado, possui um custo computacional elevado para a geração de vários cenários, não sendo conveniente para a aplicação em problemas estocásticos. Logo, nesse último caso, provou-se que a utilização de funções randômicas, que utiliza medidas estatísticas em sua sintaxe, apresentam resultados com acurácia similar ao obtido com a rede neural, porém com um baixíssimo custo computacional.

**Palavras-chave:** Geração de cenários. Geração Eólica. Preço de Liquidação das Diferenças. Redes Neurais Recorrentes.



## LISTA DE FIGURAS

Figura 1 - Estrutura do Setor Elétrico Brasileiro.....	22
Figura 2 - Cenários avaliados pelo ONS no planejamento energético. .	25
Figura 3 - Mapa de rugosidade do solo. ....	28
Figura 4 - Médias climatológicas sazonais no Brasil. ....	29
Figura 5 - Potencial eólico brasileiro. ....	30
Figura 6 - Redes neurais unidirecionais. ....	31
Figura 7 - Rede neural recorrente.....	32
Figura 8 - Variação da geração eólica ao longo do tempo. ....	34
Figura 9 - Média mensal da geração eólica. ....	35
Figura 10 - Identificação de outliers na geração eólica via BoxPlot. ....	35
Figura 11 - Variação do PLD ao longo dos anos.....	37
Figura 12 - Médias anuais do PLD.....	39
Figura 13 - Nível dos reservatórios (SE/CO) nos últimos 19 anos no mês de janeiro. ....	39
Figura 14 - Identificação de outliers no PLD. ....	40
Figura 15 - Medidas de dispersão mensais do PLD. ....	41
Figura 16 - Algoritmo da <i>toolbox</i> utilizada. ....	44
Figura 17 - Resultado do teste de confiabilidade da geração eólica.....	47
Figura 18 - RMSE da geração eólica.....	48
Figura 19 - Resultado do teste randômico da geração eólica. ....	49
Figura 20 - RMSE do teste randômico da geração eólica. ....	50
Figura 21 - Previsão de geração eólica para um horizonte de 5 anos....	51
Figura 22 - Comparação entre a previsão e dados históricos da geração eólica. ....	51
Figura 23 - Previsão randômica de 5 anos para eólica. ....	53
Figura 24 - Resultado do teste de confiabilidade para o PLD. ....	54
Figura 25 - RMSE do PLD.....	55
Figura 26 - Resultado do teste randômico para o PLD. ....	57
Figura 27 - RMSE do teste randômico do PLD. ....	58
Figura 28 - Previsão de cinco anos para o PLD. ....	59
Figura 29 - Comparação entre a previsão e dados históricos do PLD...	59

## LISTA DE QUADROS

Quadro 1 - Resumo das análises estatísticas para geração eólica (MWmed).....	36
Quadro 2 – Resumo das análises estatísticas para o PLD (R\$/MWh). .	42
Quadro 3 – Resultados da geração eólica (MWmed).....	52
Quadro 4 - RMSE médio obtido nos 50 experimentos de cada dado de entrada.....	56
Quadro 5 – Resultados do PLD (R\$/MWh).....	60
Quadro 6 - Medidas estatísticas a partir de 2015 (R\$/MWh). ....	61

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>17</b>
1.1	MOTIVAÇÃO .....	17
1.2	OBJETIVOS .....	18
<b>1.2.1</b>	<b>Objetivo geral .....</b>	<b>18</b>
<b>1.2.2</b>	<b>Objetivos específicos .....</b>	<b>18</b>
1.3	ESTRUTURA DO TRABALHO .....	18
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>21</b>
2.1	ORGANIZAÇÃO DO SETOR ELÉTRICO BRASILEIRO .....	21
2.2	FORMAÇÃO DO PREÇO DA ENERGIA ELÉTRICA .....	23
2.3	GERAÇÃO DE ENERGIA EÓLICA .....	26
2.4	REDES NEURAIS .....	31
<b>3</b>	<b>ANÁLISE DOS DADOS HISTÓRICOS.....</b>	<b>33</b>
3.1	ANÁLISE HISTÓRICA DA GERAÇÃO EÓLICA .....	33
3.2	ANÁLISE HISTÓRICA DO PLD .....	37
<b>4</b>	<b>METODOLOGIA .....</b>	<b>43</b>
4.1	TESTE DE CONFIABILIDADE DAS PREVISÕES.....	45
4.2	PREVISÃO DE DADOS PARA HORIZONTES LONGOS .....	46
<b>5</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>47</b>
5.1	PREVISÕES PARA A GERAÇÃO EÓLICA .....	47
<b>5.1.1</b>	<b>Teste de confiabilidade para geração eólica .....</b>	<b>47</b>
<b>5.1.2</b>	<b>Previsão em horizonte plurianual .....</b>	<b>50</b>
5.2	PREVISÕES PARA O PLD .....	54
<b>5.2.1</b>	<b>Teste de confiabilidade para o PLD.....</b>	<b>54</b>
<b>5.2.2</b>	<b>Previsão em horizonte plurianual.....</b>	<b>58</b>
<b>6</b>	<b>CONCLUSÃO .....</b>	<b>63</b>
	<b>REFERÊNCIAS .....</b>	<b>65</b>





# 1 INTRODUÇÃO

O Sistema Elétrico Brasileiro (SEB) é caracterizado atualmente como um sistema hidro-termo-eólico de grande porte (ONS, 2018), dominado pela fonte hidráulica que é favorecida pela existência de diversas bacias hidrográficas no país, com centenas de rios perenes e caudalosos, além da topografia favorável à construção de grandes reservatórios e dos regimes de chuvas diferentes ao longo de um mesmo ano (ENEX, 2012). Por outro lado, a geração eólica tem ganhado destaque no atendimento à demanda, devido ao crescimento da exploração do potencial eólico das regiões Nordeste e Sul (ONS, 2018). Já as usinas térmicas são responsáveis pela segurança do suprimento nacional, sendo operadas com o objetivo de otimizar o armazenamento dos reservatórios de água de acordo com as previsões hidrológicas, consequentemente reduzindo o custo operativo desse sistema (ONS, 2018).

Durante o planejamento da operação, as previsões hidrológicas não são consideradas determinísticas, isto é, não se determina a política de despacho das usinas apenas com base na realização de um único cenário hidrológico. Assim, o que se realiza na prática é a otimização de modelos matemáticos que contém os possíveis cenários para a tomada das decisões operativas (SILVA, 2001). Com a crescente penetração da geração eólica, a mesma estratégia deve ser realizada para com a previsão dos regimes dos ventos, embora atualmente os modelos de otimização do SEB utilizem apenas de um único cenário de vento (ou geração eólica). Por sua vez, o preço da energia no mercado de curto prazo, i.e., o Preço de Liquidação de Diferenças (PLD) também é influenciado pela operação do sistema. Logo, a possibilidade de melhorar o despacho da operação, através da obtenção de cenários mais precisos para inserir nos modelos determinísticos e estocásticos, é relevante para o SEB.

## 1.1 MOTIVAÇÃO

A motivação desse trabalho está em buscar entender o comportamento de parâmetros importantes ligados ao SEB, como a geração eólica e o PLD. Existem vários trabalhos que procuram determinar previsões e/ou geração de cenários desses parâmetros, embora tal procedimento ainda pode ser considerado como um desafio em aberto. Em vários trabalhos propostos, as redes neurais se mostram promissoras para resolver esse tipo de desafio, ensinando as máquinas como sistemas importantes funcionam e esperando resultados confiáveis. Por isso, nessa pesquisa pretende-se experimentar e verificar a viabilidade de usar a

inteligência artificial, por meio das redes neurais recorrentes, para gerar previsões de parâmetros relevantes para o SEB.

## 1.2 OBJETIVOS

Esse trabalho de conclusão de curso (TCC) pretende atingir os objetivos especificados detalhados a seguir.

### 1.2.1 Objetivo geral

O objetivo geral desse trabalho é verificar a viabilidade da utilização de uma rede neural recorrente para a geração de cenários discretizados mensalmente, avaliando a qualidade dos resultados para a geração eólica e o PLD, através de testes de confiabilidade e da geração de cenários com horizontes de cinco anos.

### 1.2.2 Objetivos específicos

- a) Avaliar os dados históricos de geração eólica e do PLD, através de ferramentas estatísticas;
- b) Propor um modelo de rede neural recorrente adequado para esses tipos de dados, de acordo com a literatura;
- c) Aferir o treinamento da máquina, aplicando testes de confiabilidade e verificando o nível de acerto desses testes;
- d) Comparar o nível de erro entre as previsões realizadas pela rede e as previsões geradas por funções randômicas;
- e) Verificar a precisão dos resultados da rede neural recorrente, gerando previsões para os próximos 5 anos e verificando as similaridades entre as previsões e as tendências históricas;
- f) Analisar o custo computacional envolvido no uso de redes neurais.

## 1.3 ESTRUTURA DO TRABALHO

Este trabalho está disposto em seis capítulos, sendo o primeiro capítulo composto por esta introdução. O Capítulo 2 aborda de forma geral os temas essenciais para a compreensão desse trabalho. Através de argumentos bastante difundidos na literatura, para alinhar o ambiente onde esse trabalho está inserido. É explicado como o SEB está organizado, como ocorre a formação de preços no mercado de curto

prazo, como a geração eólica está se desenvolvendo no Brasil e como as redes neurais têm se destacado no âmbito da inteligência artificial. O Capítulo 3 traz análises estatísticas sobre os parâmetros do SEB que serão testados nesse trabalho. No Capítulo 4, é apresentada a metodologia desenvolvida para atingir os objetivos dessa pesquisa e o Capítulo 5 expõe os resultados obtidos nos experimentos realizados. Por fim, a conclusão desse TCC apresenta as considerações finais acerca dos objetivos propostos para essa pesquisa e sugestões para trabalhos futuros.



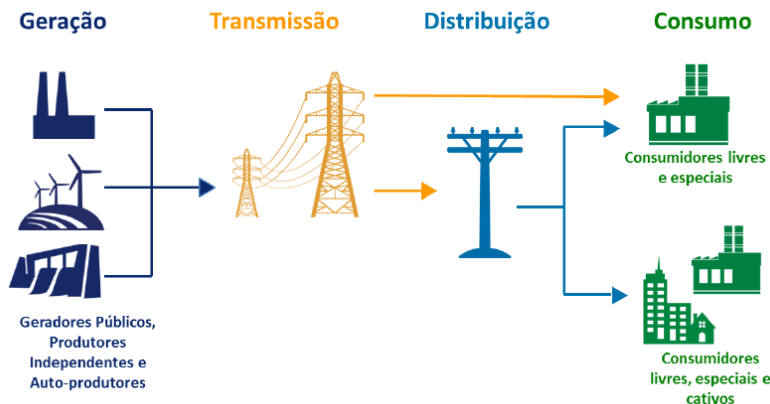
## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 ORGANIZAÇÃO DO SETOR ELÉTRICO BRASILEIRO

Com o passar dos anos, cada segmento da economia exige mudanças para continuar se desenvolvendo. Assim, na década de 90, com a necessidade de criar um mercado competitivo, o SEB precisava ser reorganizado. Era necessário substituir a visão de serviço obrigatório por uma visão de mercado, criando um mercado de energia elétrica, onde os agentes seriam orientados pelo preço. Então, para modificar a perspectiva desse segmento, foi elaborado em 1998 um projeto de Reestruturação do Setor Elétrico Brasileiro – Projeto RE-SEB, que foi fundamentado na inclusão da competição e na determinação de um preço que representasse os custos reais de produção e transporte da energia elétrica. Para isso era necessário separar a atividade de transporte desse produto, da sua atividade de produção. Então foi concluído desse projeto, a necessidade da desverticalização dos serviços do setor elétrico, ou seja, era preciso separar as atividades de geração, transmissão e distribuição, além de instituir a atividade de comercialização de energia. De modo geral, essa reestruturação tinha como objetivo reduzir o preço da energia elétrica dando aos agentes livre acesso à transmissão, obter ganhos de eficiência em todo o setor e também atrair investimentos de capital privado (SILVA, 2001).

Apenas em 2004 um novo modelo setorial entrou em vigência no Brasil (ENEX, 2012). Nesse modelo, os serviços para atender a demanda dos consumidores não eram mais realizados por apenas um agente. Hoje se têm definidos os quatro segmentos do setor elétrico: geração, transmissão, distribuição e comercialização. A geração é composta por geradores públicos, produtores independentes e autoprodutores. O serviço de transporte é responsabilidade das empresas de transmissão e distribuição. A comercialização da energia pode ser realizada em dois ambientes: em um ambiente de livre contratação de energia, constituído por consumidores livres e especiais e em um ambiente regulado, composto por consumidores cativos (CCEE, 2018). A organização do SEB atual é ilustrada pela Figura 1.

Figura 1 - Estrutura do Setor Elétrico Brasileiro.



Fonte: Câmara de Comercialização de Energia Elétrica (2017).

No Brasil os grandes consumidores fazem parte do modelo que segue a tendência da indústria de energia elétrica contemporânea, onde a livre concorrência para comprar e vender a energia elétrica é sua característica fundamental, sendo necessário que cada atividade da indústria seja exercida de forma independente. Com isso, os agentes de geração e comercialização possuem livre competição, não sendo uma atividade regulada economicamente. Já os agentes de transporte (transmissão e distribuição) são monopólios naturais, portanto não há competição nesses seguimentos, por isso é necessário que esses serviços sejam regulados tecnicamente e economicamente, para trazer o retorno financeiro de custo de capital, operação e manutenção, além de oferecer serviços tecnicamente eficientes e de qualidade (SILVA, 2001).

Logo, para o desempenho correto desse mercado são necessários outros agentes no setor elétrico com atividades bem definidas. Assim, foi criada em 1997 a Agência Nacional de Energia Elétrica (ANEEL), órgão que regula o SEB, sendo responsável por regular os quatros seguimentos do setor. Também fiscaliza as concessões e a qualidade dos serviços de energia elétrica, determina as tarifas e implementa as diretrizes do governo federal em relação à exploração da energia elétrica (ANEEL, 2018).

Em 1998 surge o Operador Nacional do Sistema Elétrico (ONS), que hoje é responsável pelo planejamento e programação da operação, realizando o despacho centralizado da geração de energia e garantindo a

segurança do suprimento contínuo no Brasil. O objetivo do trabalho do ONS é otimizar a operação do sistema eletroenergético com o menor custo de operação possível, atendendo as normas de confiabilidade aprovadas pela ANEEL. Com isso, o ONS pode contribuir para a expansão do Sistema Interligado Nacional (SIN), visando melhoras na operação do sistema e baixo custo de implantação, além de garantir que todos os agentes do setor tenham acesso à rede de transmissão de forma não discriminatória (ONS, 2018).

Outro importante agente para a formação do mercado de energia é a Câmara de Comercialização de Energia Elétrica (CCEE), que viabiliza as atividades de comercialização de energia no país. Também é responsável pela medição de energia gerada no sistema, contabilização da energia consumida, pela liquidação financeira dos contratos de compra e venda de energia no mercado de curto prazo e por promover leilões de energia conforme delegado pela ANEEL. Assim, a modicidade tarifária e a garantia do fornecimento universal, que foram os pilares da reestruturação do sistema na década de 90, só são possíveis com a existência da CCEE (CCEE, 2018).

## 2.2 FORMAÇÃO DO PREÇO DA ENERGIA ELÉTRICA

A operação do SIN é realizada de forma centralizada pelo ONS, com o objetivo de otimizar o uso dos recursos de geração com o menor custo operativo total e atender a demanda. Essa é principal ideia da corrente de mercado de energia elétrica adotada pelo Brasil na época da reestruturação do setor, o chamado mercado *Pool*. Esse modelo é diferente do mercado Bilateral adotado em grande parte da Europa, onde não existe uma centralização do uso dos recursos, o que permite a livre negociação entre os geradores e os consumidores, operando esse mercado através da oferta e da demanda (SILVA, 2001).

Como o SIN é predominantemente hidrotérmico, existe uma grande incerteza relacionada ao custo do uso da energia elétrica, já que existem muitas incertezas vinculadas aos níveis pluviométricos e a matriz energética é composta principalmente por bacias hidrográficas. Dado esse contexto, um mercado com preços de curto prazo tão voláteis poderia expor os agentes desse sistema a inaceitáveis riscos, levando agentes produtores a não conseguirem entregar a energia contratada e consumidores a não conseguirem pagar por tarifas de energia tão elevadas. Além disso, as bacias hidrográficas são formadas por usinas em cascatas pertencentes a diferentes donos. Dessa forma, implantar um modelo Bilateral nesse sistema não seria viável, principalmente em uma

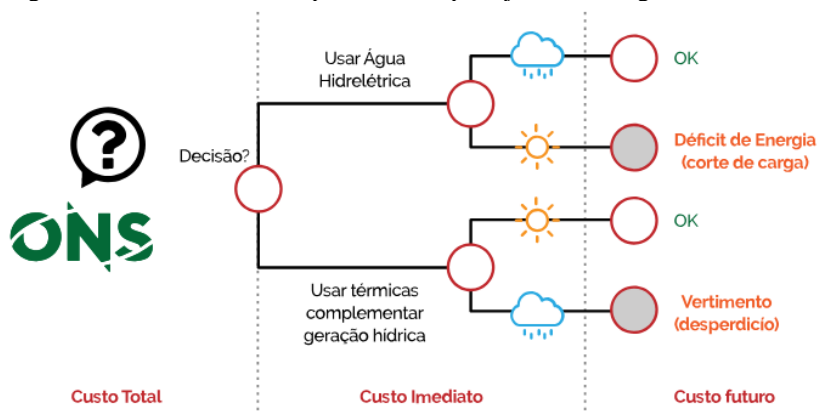
fase de reestruturação e implantação de um mercado competitivo, como a que o Brasil vivia na época (SILVA, 2001).

Para operar esse complexo sistema, são tomadas decisões ótimas através de modelos computacionais, que tem como objetivo a minimização dos custos de geração. Dessa forma, em um sistema hidrotérmico como o Brasileiro, o menor custo de produção de energia elétrica é obtido através do uso adequado da água (CCEE, 2018). Entretanto, apenas com o uso da água não é possível atender toda a demanda e nem possuir um sistema com alta confiabilidade de suprimento de energia. Assim, são acrescentadas usinas termelétricas nesse sistema, que são despachadas por ordem de mérito para atender o critério de minimização de custos operativos. Logo, são utilizadas primeiro as usinas mais baratas e em seguida despachadas usinas na ordem crescente de custo para atender toda a demanda (SILVA, 2001).

Outro fator que influencia no despacho desse sistema são as incertezas associadas as vazões afluentes aos reservatórios. Ainda que haja água suficiente para suprir toda a demanda, não é uma boa decisão utilizar toda a água para gerar energia no presente, pois no futuro pode ocorrer um período de estiagem, tornando obrigatório o uso de fontes de geração térmica com custos de combustíveis elevados. Porém, em outro cenário, onde a água é poupada para o futuro e ocorre um período com altos níveis pluviométricos, a água acabará sendo vertida, que caracteriza uma operação não otimizada. Dessa forma, pode-se observar que a operação de sistemas hidrotérmicos é acoplada no tempo e as decisões devem ser tomadas considerando as consequências nos cenários futuros (Figura 2), que influenciarão no custo desse sistema, devido aos custos dos combustíveis utilizados e dos eventuais déficits (CCEE, 2018). Logo, é um grande desafio para o ONS planejar e decidir o melhor uso dos recursos de geração com um baixo custo e alta confiabilidade.



Figura 2 - Cenários avaliados pelo ONS no planejamento energético.



Fonte: Instituto de Energia e Meio Ambiente (2018).

Além dos regimes pluviométricos, o regime dos ventos também gera incerteza na operação do sistema. Como a geração eólica não pode ser armazenada, matematicamente a mesma é modelada como uma demanda negativa; ademais, ainda não está sendo incluída nos cenários de incerteza. Como a geração eólica tem se tornado uma opção de geração de destaque na matriz energética, é importante para o mercado incluir os cenários de geração eólica. Com isso, pode-se concluir que existem vários cenários possíveis para geração de energia elétrica e a cada cenário está associado um Custo Marginal de Operação (CMO), que é um subproduto dessas decisões operativas. O CMO é definido como o custo da termelétrica mais cara que será despachada para atender um acréscimo na demanda (ANEEL, 2004). Logo, como as usinas são despachadas por ordem de mérito nesse modelo de mercado, a remuneração dos gastos dos geradores é feita através do CMO da última usina despachada naquela operação, fazendo com que todas as usinas recebam o mesmo pagamento por sua atividade. Esse mecanismo assegura que o agente repassará o preço da sua energia próximo ao custo da sua produção, pois caso ele repasse um valor muito acima do mercado, sua usina não será despachada durante a operação. Por outro lado, se ele oferecer sua energia com um preço abaixo do mercado e ainda assim sua usina for a mais cara despachada no período, esse agente arcará com seu prejuízo, pois a remuneração é igual para todos os agentes despachados (SILVA, 2001).

Existe um CMO para cada período analisado, com valores distintos para cada patamar de carga e em cada submercado. São definidos três

patamares de carga, que estão associados aos diferentes períodos de consumo de energia elétrica durante um dia: leve (baixo consumo), médio (consumo nominal) e pesado (horários com picos de consumo). E devido as limitações do sistema de transmissão, são definidos pelo ONS os quatro submercados do sistema brasileiro: Norte, Nordeste, Sudeste/Centro-Oeste e Sul, podendo haver intercâmbios de energia entre os submercados quando necessário (CCEE, 2018).

O CMO serve como base para a formação do PLD, sendo que este último serve para precificar toda a energia que não foi contratada e que é liquidada entre os agentes. O PLD é definido semanalmente através das previsões de disponibilidade de energia e carga, mediante ao uso daqueles mesmo modelos computacionais que auxiliam o despacho de geração. Dessa forma, o PLD acompanha o CMO, mas é limitado por valores máximos e mínimos. Assim o PLD não pode ser igual a zero quando há vertimento da água nas usinas e também não pode possuir um valor muito elevado em um período de racionamento, onde o CMO pode chegar próximo de mil reais por MWh (CCEE, 2018). Assim esses limites definidos na Resolução nº 633/2014 da ANEEL, servem como forma de proteção desse sistema. Devido à complexidade da formação de preços e seu impacto no mercado de energia, esse trabalho pretende analisar o comportamento do preço do mercado de curto prazo ao longo dos anos e tentar gerar cenários para os próximos anos, que poderiam auxiliar na tomada de decisões de geradores e comercializadores de energia.

## 2.3 GERAÇÃO DE ENERGIA EÓLICA

A energia proveniente dos ventos tem se tornado cada vez mais expressiva na composição da matriz energética brasileira. Em 2018 com 14,3 GW de capacidade instalada em 568 parques eólicos, o Brasil conta com 9% da produção de energia através dos ventos em sua matriz (ABEEÓLICA, 2018). Estima-se que o grande potencial eólico brasileiro seja cada vez mais explorado, sendo que para 2020 a expectativa é que o país tenha 600 parques eólicos instalados, que contribuirão com o atendimento de 17,9 GW de potência, aumentando a fração de participação da energia eólica para 10% do total de toda a energia produzida no sistema brasileiro (CASA DOS VENTOS, 2018).

O grande potencial eólico disponível no território nacional foi constatado através de análises de dados relativos à intensidade da velocidade dos ventos, sua direção, relevo do território, rugosidade do solo e outros fatores particulares de cada localidade estudada. No passado, as estações anemométricas captavam informações para a formulação de

um inventário sobre o potencial eólico Brasileiro. Os primeiros dados obtidos na década de 70, mostravam velocidades médias anuais em torno de 4 m/s à 10m de altura, já indicando viabilidade técnica no uso de energia eólica de pequeno porte para sistemas isolados, principalmente no litoral nordestino. Na década de 80 foi verificada a tendência de velocidades maiores de vento no litoral brasileiro e também em áreas do interior favorecidas pelo relevo e pela baixa rugosidade. Porém, essas medições foram feitas a 10 m de altura, onde obstáculos locais poderiam interferir na velocidade dos ventos. Com a instalação das primeiras usinas eólicas no Brasil, um estudo aprofundado foi realizado com a instalação de torres anemométricas de 30 a 50m, e foi verificado maior viabilidade em locais de dunas com baixíssima rugosidade no litoral cearense, marcando velocidades médias anuais de 9 m/s (AMARANTE et al., 2001).

Posteriormente foram desenvolvidos modelos que simulavam a dinâmica atmosférica dos regimes dos ventos, utilizando informações sobre as características da superfície, como no software MesoMap. Assim, através de simulações nesse software, foram elaborados os mapas de potencial eólico, que deram origem ao Atlas do Potencial Eólico Brasileiro. Na Figura 3 pode ser observado um mapa resultante desses estudos, que indicam que as regiões amareladas do mapa apresentam melhores índices de vento, por serem áreas de menor rugosidade no solo. Destacam-se nesse mapa a Região Nordeste e o Rio Grande do Sul (AMARANTE et al., 2001).

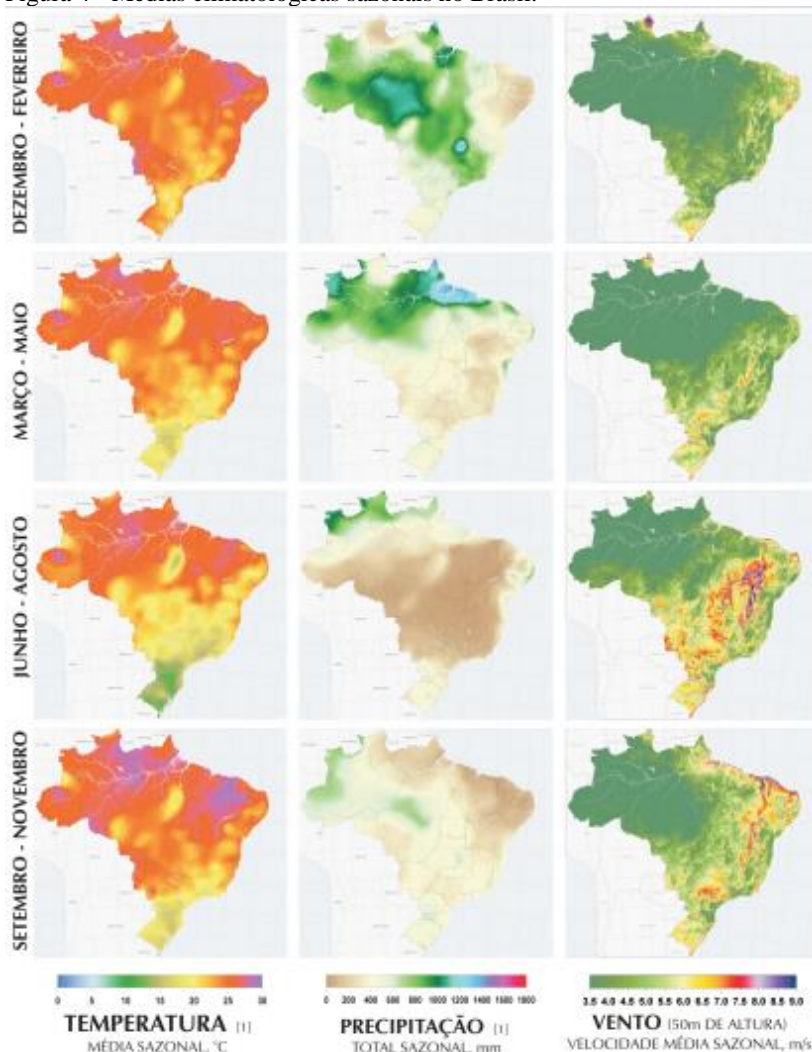
Figura 3 - Mapa de rugosidade do solo.



Fonte: Atlas do Potencial Eólico Brasileiro, 2001.

Também foi observado nesse mapeamento as velocidades médias sazonais de vento (medições a 50m de altura), identificando uma complementaridade entre os regimes de chuvas e de ventos. As principais bacias hidrográficas brasileiras estão localizadas em regiões com estações bem definidas, a estação seca (abril a setembro) e a chuvosa (novembro a março), fator que impacta na matriz energética brasileira, que é majoritariamente hidráulica. Pode-se notar na Figura 4 que a velocidade média dos ventos aumenta na estação seca. A geração eólica também é complementar à hidráulica no que diz respeito a posição geográfica das usinas no sistema elétrico. Como foi destacado, o litoral favorece a geração eólica, podendo fornecer energia aos extremos do sistema brasileiro, que estão distantes da geração hidrelétrica. Logo a exploração desse potencial eólico aumenta a estabilidade de oferta de energia por fontes renováveis (AMARANTE et al., 2001).

Figura 4 - Médias climatológicas sazonais no Brasil.

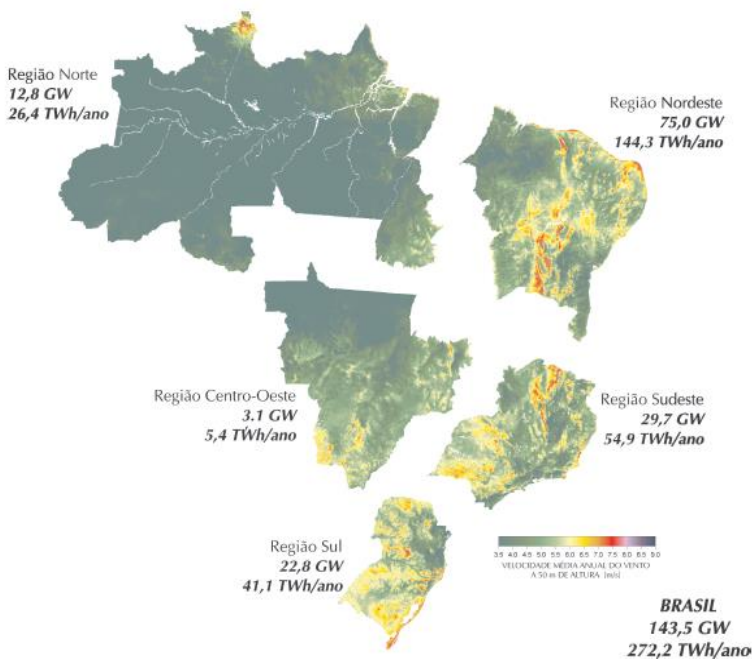


Fonte: Atlas do Potencial Eólico Brasileiro, 2001.

Portanto, foi calculado em 2001 no Atlas do Potencial Eólico Brasileiro a capacidade de produção eólica anual das regiões brasileiras, considerando a geometria e altitude dos terrenos, a vegetação e utilizando cálculos de desempenho de turbinas eólicas existentes no mercado, que

mostram os grandes índices de geração das regiões Nordeste, Sudeste e Sul (AMARANTE et al., 2001), como mostra o mapeamento da Figura 5:

Figura 5 - Potencial eólico brasileiro.



Fonte: Atlas do Potencial Eólico Brasileiro, 2001.

Em vista disso, a energia eólica se apresenta como uma importante alternativa a geração hidrelétrica, por complementar a sazonalidade do regime pluviométrico, pela posição geográfica das usinas, pelo seu baixo custo e por seu grande potencial de geração no Brasil. Consequentemente, a crescente inserção de energia eólica no sistema elétrico brasileiro e a implantação de modelos horários de precificação da energia, demonstram a importância de estudar o desempenho da geração eólica e de tentar prevê-la para melhorar a operação do SEB. Por isso, o comportamento dessa fonte renovável será o outro objeto de estudo desse trabalho, buscando determinar cenários de geração eólica que poderiam ser inseridos no planejamento da operação energética.


## 2.4 REDES NEURAIS

O conceito de redes neurais artificiais (RNAs) consiste em substituir o desenvolvimento de um programa de computador que tenta resolver problemas de forma inteligente, como nos algoritmos que são utilizados no dia a dia da engenharia, por um computador que possui circuitos que modelam as conexões cerebrais. Diante disso, as RNAs apresentam a capacidade de desenvolver a sua inteligência através do aprendizado. O aprendizado da máquina ocorre através da assimilação de novas tarefas, dos erros cometidos e das descobertas realizadas nesse processo. Assim, são capazes de se adaptar a novas situações, se reorganizando e apresentando comportamentos inesperados (BARRETO, 2002).

Os modelos computacionais contêm uma estrutura similar à do cérebro humano (NELSON, 2017). Eles são compostos por elementos que sofrem excitações exteriores, chamados neurônios de entrada, e se assemelham aos órgãos dos sentidos humanos, combinados com os neurônios de saída, que correspondem aos músculos, e possuem a capacidade de alterar o mundo externo com as respostas obtidas (BARRETO, 2002). Além disso, esses modelos matemáticos são constituídos por funções de ativação, que representam as reações químicas que correm no corpo humano, sendo encarregados de transportar as informações entre os neurônios (NELSON, 2017).

Durante o treino da máquina são atribuídos pesos para cada neurônio, que são definidos através da compreensão dos exemplos fornecidos a RNA, a qual otimiza esses pesos estipulados, com o objetivo de mitigar os erros para os novos exemplos que serão inseridos na rede. Desse modo, o funcionamento da RNA ocorre em um único sentido (Figura 6), onde as informações são inseridas no neurônio de entrada e multiplicadas pelo peso dessa camada, repassando essa informação através das conexões diretas entre os neurônios (NELSON, 2017).


Figura 6 - Redes neurais unidirecionais.



Fonte: Barreto (2002).

Além das RNAs, existem as redes neurais recorrentes, que são capazes de se comunicar com as camadas anteriores ao seu neurônio de entrada, realizando fluxos cíclicos (Figura 7), ou seja a resposta da saída não depende somente da entrada presente, mas também recebe informações das camadas anteriores (NELSON, 2017). Essa habilidade fornece uma memória de curto prazo para a rede, característica que será relevante para a definição da metodologia desse trabalho.

Figura 7 - Rede neural recorrente.



Fonte: Nelson (2017).

Porém, as redes neurais recorrentes apresentam problemas durante o treinamento de grandes sequências de dados, quando são utilizados métodos com gradientes durante o processo, causando o desaparecimento do fluxo de erro durante o aprendizado. Esse problema foi corrigido pela rede *Long Short – Term Memory* (LSTM), que mantém esse fluxo constante, através dos ajustes nos pesos e da realização de truncamentos nessas sequências se a informação fornecida for considerada desnecessária (NELSON, 2017). Essa inteligência também ajudará na escolha dos procedimentos desse trabalho.

A inteligência artificial tem sido estudada em várias áreas da engenharia. É utilizada para modelagens florestais, sendo empregues por Araújo (2016) e Silva et al. (2016) para realizar estimativas volumétricas de eucaliptos. Quiroz (2017) utilizou diferentes tipos de RNAs para previsão de geração eólica e no campo da economia Nelson (2017) aplicou as redes neurais recorrentes para previsão de séries temporais financeiras. Esses trabalhos apresentam bons resultados para realização de estimativas com o uso das redes neurais. Por isso, esse TCC busca estudar a aplicação de redes neurais recorrentes para prever parâmetros importantes do SEB.



### 3 ANÁLISE DOS DADOS HISTÓRICOS


Este trabalho irá discutir o uso de redes neurais recorrentes (RNRs) para gerar cenários discretizados mensalmente de geração eólica para os próximos cinco anos. O mesmo método será aplicado para previsão do PLD em um horizonte de igual magnitude. Este capítulo detalha o comportamento dos dados históricos desses parâmetros, analisando como isso poderá impactar na geração de cenários futuros, quando esses dados são utilizados como o parâmetro de entrada de um modelo computacional.

Para gerar cenários de séries temporais de um determinado evento é necessário fazer uma análise estatística dos seus dados históricos, através da avaliação da variabilidade desses dados, da verificação da existência de outliers e da determinação de suas medidas de dispersão. Essa análise estatística inicial serviu para aferir os resultados previstos nesse trabalho, comparando as tendências estatísticas identificadas nos dados históricos com o resultado da aplicação de redes neurais recorrentes para gerar os cenários futuros.

#### 3.1 ANÁLISE HISTÓRICA DA GERAÇÃO EÓLICA

A geração eólica está associada à um fenômeno da natureza, sendo um sistema dependente da regularidade dos ventos. Atualmente no SIN, a energia eólica é considerada como um abatimento da demanda da carga, ou seja, sempre que há disponibilidade de vento a energia é gerada e introduzida no sistema para atender a demanda. Mas a inconstância dos ventos faz com que a geração de energia varie ao longo do tempo, como mostra a Figura 8. Nesse gráfico é apresentada uma amostra constituída por 95 medidas de geração eólica na Usina Praia Formosa, localizada no estado do Ceará e pertencente ao subsistema Nordeste. A discretização desses dados históricos é mensal e compreende o período de outubro de 2010 a julho de 2018, estando disponível na plataforma online do ONS.


Figura 8 - Variação da geração eólica ao longo do tempo.



Fonte: Elaborada pela autora (2018).

Para compreender os pontos de máximo e mínimo mostrados no gráfico acima, Favera et al. (2010) analisa o comportamento estatístico anual e sazonal dos ventos e mostra que o maior potencial eólico está concentrado durante os trimestres da primavera e do inverno, pois nesse período a densidade de potência e a velocidade dos ventos é maior. Por isso ao avaliar os 95 dados históricos, expondo-os mensalmente como na Figura 9, é observado esse padrão na geração eólica. Como citado anteriormente, de julho a dezembro ocorre um aumento na geração eólica, que vai diminuindo ao longo do período até a chegada do verão, onde há menor incidência dos ventos. Essa tendência estatística ajuda a identificar as fontes potenciais de variabilidade desse sistema, que devem se repetir nas previsões para horizontes longos.


Figura 9 - Média mensal da geração eólica.



Fonte: Elaborada pela autora (2018).

Ao avaliar os 95 dados mensais dessa amostra, através de ferramentas estatísticas, não são identificados dados discrepantes ao longo do período, pois utilizando a ferramenta Box Plot (Figura 10), não são identificados outliers nessa amostra, podendo-se concluir que isso evitará a presença de anomalias nos resultados das previsões, ao usar esses dados como entrada de um modelo computacional.

Figura 10 - Identificação de outliers na geração eólica via BoxPlot.



Fonte: Elaborada pela autora (2018).

Dividindo esses dados em quarto partes iguais (quartis), é identificado pelo quartil 1 que 25% dos dados estão distribuídos abaixo de 16,27 MWmed. E pelo quartil 3, sabe-se que 25% dos dados estão acima de 44,37 MWmed. Além disso, observando a tendência central desses dados, verifica-se que a mediana é 28,81 MWmed, ou seja, têm-se 50% dos dados acima e 50% abaixo desse valor. Pelo desenho do diagrama de caixa acima, pode-se observar a simetria da mediana em relação aos quartis, inferindo uma grande variabilidade dos dados, que são confirmadas quando é calculada a amplitude dos dados dessa amostra. O valor mínimo encontrado é igual a 4,67MWh e o valor máximo igual a 54,74 MWmed, resultando em uma amplitude total de 50,07 MWmed.

Quando são calculadas as medidas de dispersão da amostra total da geração eólica, encontra-se um valor de média igual a 30,38 MWmed e um desvio padrão de 15,58 MWmed. Entretanto, é importante conhecer as medidas estatísticas mensais da geração, para comparar com os cenários de geração eólica que serão produzidas nesse trabalho. Assim, foram resumidas no Quadro 1 as análises mensais, utilizando todos os dados da Usina Praia Formosa.

Quadro 1 - Resumo das análises estatísticas para geração eólica (MWmed).

Mês	Média	Variância	Desvio Padrão	Mínimo	Máximo
Jan	29,98	112,08	10,59	12,42	44,21
Fev	21,39	70,01	8,37	8,55	31,42
Mar	15,27	51,78	7,20	6,66	28,57
Abr	10,75	22,59	4,75	4,67	19,25
Mai	14,76	59,44	7,71	5,04	27,83
Jun	20,57	32,08	5,66	11,65	29,05
Jul	24,77	67,93	8,24	13,07	35,96
Ago	39,84	15,41	3,93	34,73	44,86
Set	46,66	50,64	7,12	36,53	54,74
Out	48,57	26,64	5,16	42,15	54,47
Nov	49,97	13,27	3,64	42,24	54,13
Dez	45,25	67,74	8,23	32,06	53,92
<b>Total</b>	<b>30,38</b>	<b>242,58</b>	<b>15,58</b>	<b>4,67</b>	<b>54,74</b>


Fonte: Elaborado pela autora (2018).

É interessante notar nesse quadro, que de janeiro a julho as médias de geração eólica mensais estão abaixo da geração média anual, confirmando a baixa intensidade de ventos nos trimestres do verão e do outono. O caso inverso pode ser observado de agosto a dezembro.

### 3.2 ANÁLISE HISTÓRICA DO PLD

A formação do preço da energia elétrica no mercado de curto prazo, também conhecido como preço *spot*, é composta por muitas fontes de incerteza como já mencionado na revisão bibliográfica desse trabalho. Mas é importante reforçar alguns fatores que influenciam nesse preço e que ajudam a interpretar o gráfico mostrado na Figura 11. Esse gráfico contempla uma amostra formada por dados de 904 semanas do PLD do subsistema Sudeste/Centro-Oeste no patamar de carga pesado, durante o período de julho de 2001 a agosto de 2018.

Figura 11 - Variação do PLD ao longo dos anos.



Fonte: Elaborada pela autora (2018).

A variação do preço *spot* é influenciada pelas decisões operativas do sistema, que deve otimizar a oferta dos geradores para atender a demanda. Ou seja, no mercado *tigh pool* Brasileiro, as usinas hidrelétricas (UHEs) oferecem para o operador a sua disponibilidade e as usinas termelétricas (UTES) o seu Custo Variável Unitário (CVU), que é referente ao custo necessário para gerar energia elétrica através do combustível utilizado. A disponibilidade de geração das UHE está


associada à um fenômeno da natureza, o regime das chuvas, que é marcado por períodos úmidos (verão) e secos (inverno) e revelam um padrão de ocorrência. Porém, quem precisa comprar energia no mercado *spot* não encontra a *commodity* precificada somente de acordo com as teorias da microeconomia de oferta e demanda, pois não existe um preço padrão para cada sazonalidade. De acordo com a disponibilidade de recursos hídricos no presente e avaliando os cenários de risco hidrológico no futuro, a CCEE utiliza de modelos computacionais para minimizar o custo operativo do sistema<sup>1</sup>, despachando as UTE por ordem de mérito, de forma que o custo no futuro também seja o menor possível, de acordo com as previsões hidrológicas. Dessa forma, o preço varia com a necessidade de acionar usinas mais caras para atender a demanda. Mas além disso, a operação nem sempre ocorre como o mercado gostaria, pois, o sistema possui restrições no transporte. Devido as perdas nas linhas de transmissão, para manter os níveis de tensão nas barras, as redes possuem restrições que nem sempre permitem que toda a energia seja produzida pela usina mais barata disponível. Havendo novamente a necessidade de subir o custo marginal de operação, acionando usinas com custo de operação mais elevado (SILVA, 2001).

Ao observar o gráfico da variação do PLD ao longo dos anos, são verificados que alguns períodos apresentaram preços discrepantes. Para entender melhor o ocorreu nesses picos de preço, é mostrado na Figura 12 a média anual do PLD, que evidência os anos com preços mais críticos. Pode-se citar, por exemplo, o período do racionamento que foi de maio de 2001 a fevereiro de 2002. Essa crise energética foi instaurada quando a falta de planejamento da expansão do setor elétrico foi aliada a um período seco, com reservatórios abaixo do nível de confiabilidade de suprimento. Nesse período, com a exigência do corte de 20% da carga brasileira (Sauer et al., 2001), quem precisava contratar energia no mercado *spot* estava exposto a um alto preço.

---

<sup>1</sup> Mais precisamente, também é considerando no critério o CVaR, o qual é uma medida de risco associada com o valor esperado de  $k$  “piores” cenários.


Figura 12 - Médias anuais do PLD.



Fonte: Elaborada pela autora (2018).

Nos últimos anos outras crises energéticas elevaram o PLD novamente, como a crise de abastecimento de gás e os baixos níveis dos reservatórios brasileiros, devido ao atraso da chegada do período úmido. Na Figura 13 observa-se que desde 2013 o nível dos reservatórios do subsistema Sudeste tem ficado abaixo da média no alto verão:

Figura 13 - Nível dos reservatórios (SE/CO) nos últimos 19 anos no mês de janeiro.



Fonte: Panorama Comerc (2018).


Nesses períodos não houve racionamento de energia como aconteceu em 2001, mas o risco hidrológico elevou o CMO de forma significativa. Além das crises energéticas, influências políticas que desequilibram os leilões de energia das distribuidoras (Mayon, 2018), fizeram com que o PLD atingisse o valor máximo de R\$ 822,83 /MWh

em fevereiro de 2014. Devido a esses preços tão voláteis, a ANEEL estabeleceu a Resolução Normativa nº 633/14, que determinou limites para o PLD e são calculados anualmente. Para o ano de 2018, a agência homologou os limites de máximo e mínimo em R\$ 505,18 /MWh e R\$ 40,16 /MWh respectivamente. Com essa nova regulamentação, tem-se uma nova amplitude para a variação dos preços, em torno de R\$ 470 entre o preço mínimo e o máximo.

Dessa forma, conclui-se que a determinação do PLD não está associada apenas a aspectos metodológicos dos modelos de otimização, em especial das vazões afluentes, que poderiam ter um comportamento previsto mais facilmente, como ocorre na geração eólica. No caso do PLD existem variações no custo dos combustíveis, restrições elétricas, mudanças na regulamentação do sistema, influências políticas e influências de mercados externos, que dificultam a estimativa do preço da energia para horizontes longos.

Como não foram identificadas tendências históricas no preço *spot*, será feita a avaliação dessa amostra de dados através das mesmas ferramentas estatísticas que foram usadas para examinar a geração eólica. Como citado anteriormente, o PLD apresenta algumas disparidades, que são classificadas como outliers quando o gráfico da Figura 14 é observado. É importante salientar que a presença de outliers nessa amostra pode causar falhas na previsão de futuros cenários de preço, uma vez que essas discrepâncias podem ou não se repetir no futuro, dado a natureza desses dados.

Figura 14 - Identificação de outliers no PLD.




Fonte: Elaborada pela autora (2018).



Avaliando a amostra total, formada pelos 904 dados da CCEE, calcula-se através dos quartis que 25% dos dados encontram-se abaixo de R\$ 23,37 MWh e 25% estão acima de R\$ 227, 11 MWh. A tendência central é igual a R\$ 87,07MWh, valor calculado através da mediana. Além dessa visão geral da amostra, os dados foram discretizados mensalmente para examinar seu comportamento ao longo dos anos (Figura 15).

Figura 15 - Medidas de dispersão mensais do PLD.



Fonte: Elaborada pela autora (2018).

Com isso, foram calculadas as medidas estatísticas por mês dos dados de PLD no Sudeste e resumidos no Quadro 2:

Quadro 2 – Resumo das análises estatísticas para o PLD (R\$/MWh).

Mês	Média	Variância	Desvio Padrão	Mínimo	Máximo
Jan	154,28	30035,69	173,31	4,00	569,59
Fev	138,77	41458,38	203,61	4,00	822,83
Mar	148,58	40428,22	201,07	4,00	822,83
Abr	133,93	40709,25	201,77	4,00	822,83
Mai	181,36	52812,52	229,81	6,73	822,83
Jun	140,17	23843,56	154,41	9,40	597,66
Jul	167,31	40547,69	201,36	12,28	734,87
Ago	200,41	55519,18	235,63	9,51	817,53
Set	194,92	46816,28	216,37	4,99	778,34
Out	191,99	42457,55	206,05	4,00	822,83
Nov	202,37	43324,66	208,15	6,15	822,83
Dez	144,02	24706,29	157,18	4,00	677,68
<b>Total</b>	<b>166,71</b>	<b>40423,30</b>	<b>201,06</b>	<b>4,00</b>	<b>822,83</b>

Fonte: Elaborado pela autora (2018).

Observa-se que as médias de preços nos meses mais secos são maiores. Porém, o desvio padrão é maior que a média em todos os meses, enfatizando a grande variabilidade desses dados, o que prejudica a identificação de um padrão de ocorrência dos dados.

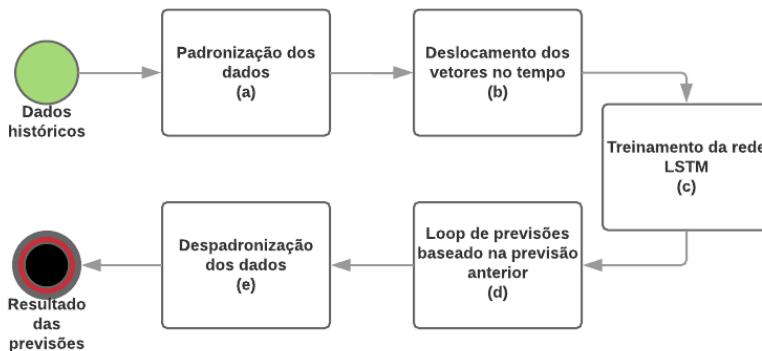
## 4 METODOLOGIA

Nesta seção será descrita a metodologia adotada para realizar os objetivos desse TCC. Após a análise histórica e estatística da geração eólica e do PLD, tem-se uma direção para os resultados desse estudo, que busca utilizar redes neurais para gerar cenários futuros coerentes com as séries históricas.

Como foi analisado previamente, a natureza dos dois dados estudados é bastante distinta. Logo, são esperados comportamentos diferentes para a mesma metodologia aplicada. Ainda assim, nos dois casos têm-se séries temporais. Por essa razão, Nelson (2017) cita que o uso de RNRs tem se mostrado mais adequado para esse tipo de problema, pois possui memória de curto prazo, diferente de outros tipos de redes neurais. Essa característica é importante para gerar bons cenários, pois além do que é aprendido durante a fase de treinamento, a RNR é capaz de considerar mudanças recentes para gerar a próxima previsão (NELSON, 2017). Desse modo, foi escolhido uma RNR chamada *Long Short Term Memory* (LSTM). Esse modelo de rede também possui a capacidade de separar acontecimentos recentes e distantes e atribuir valores diferentes para essas ocorrências, além de desprezar memórias que possam ser insignificantes para estimar a próxima saída. Assim, esse algoritmo é mais indicado quando são usadas séries temporais longas, quando comparados com outros tipos de redes neurais (NELSON, 2017), o que justifica a escolha da rede LSTM para esse trabalho.

Portanto, os dados históricos foram inseridos em uma *toolbox* de redes neurais do *software* Matlab R2018a, que utiliza uma biblioteca da rede LSTM disponível nessa versão do programa. Foram empregadas as configurações padrão presentes no algoritmo utilizado para previsão de séries temporais. Essa rede LSTM será alimentada na camada de entrada com os dados históricos, utilizará 200 camadas ocultas entre os neurônios de entrada e de saída, e apresentará uma previsão com um horizonte configurável na camada de saída. A rede foi treinada com essas configurações por 250 iterações e o tempo necessário para realizar esse processo depende da quantidade de dados inseridos na camada de entrada. O algoritmo dessa *toolbox* segue o raciocínio da Figura 16:

Figura 16 - Algoritmo da *toolbox* utilizada.



Fonte: Elaborada pela autora (2018).

- a) Após a inserção da série histórica os dados são padronizados, subtraindo o dado da média e dividindo pelo desvio padrão, colocando todos os valores na mesma base para evitar problemas de precisão;
- b) Em seguida, os dados são armazenados em dois vetores: o vetor “X”, que parte do primeiro dado até o penúltimo, e o vetor “Y”, que está deslocado de um intervalo de tempo em relação ao primeiro vetor. Ou seja, parte do segundo valor até o último da série histórica;
- c) Na etapa de treinamento, o vetor X alimenta o neurônio de entrada da rede que gera um vetor de previsão no neurônio de saída e compara esse resultado com os valores do vetor Y. Ao realizar esse processo, a rede identifica suas previsões erradas e tenta se corrigir para a próxima iteração;
- d) Após o treino, é empregada uma função que utiliza os dados na sua entrada para presumir o valor da próxima etapa de tempo. Para gerar horizontes longos, pode ser realizado um loop com essa função, onde cada nova previsão utiliza o valor estimado anteriormente como entrada;
- e) Por fim, os dados são despadronizados e temos como resultado um vetor de previsões feitas pela rede LSTM.

Para avaliar os cenários produzidos são feitos dois tipos de testes. O primeiro tem o objetivo de garantir a confiabilidade das previsões feitas pela rede neural. O segundo teste tem o propósito de gerar os próximos

cinco anos dessas séries históricas, mês a mês, e verificar se existe fundamento nessas estimativas. A seguir será explicado como esses testes foram configurados e aplicados.

#### 4.1 TESTE DE CONFIABILIDADE DAS PREVISÕES

O primeiro teste realizado foi denotado como teste de confiabilidade. O objetivo desse teste é utilizar os primeiros 90% dos dados históricos para treinar a rede e gerar previsões para os 10% restantes, comparando o valor histórico e o valor previsto. Para isso, são definidas algumas configurações no algoritmo do fluxograma descrito pela Figura 16. A primeira customização é a utilização de apenas 90% dos dados na entrada. A segunda é a definição do número de iterações do loop de previsões, que será igual ao período de tempo de 10% dos dados históricos. Esse vetor resultante é comparado com os dados originais, calculando a diferença entre o valor esperado e o valor estimado, através da *root mean square error* (RMSE), que é definido, em %, como:

$$RMSE = \frac{100}{\bar{Y}_{pred}} \times \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{pred_i} - Y_{ref})^2} \quad (1)$$

Em que:

$Y_{pred_i}$  valor previsto do  $i$ -ésimo dado;

$Y_{ref}$  valor esperado;

$\bar{Y}_{pred}$  média dos valores previstos;

$N$  número de dados.

Foi constatado que em cada treino da rede neural, obtém-se uma previsão diferente na saída. Portanto, para apresentar os resultados obtidos nesse teste, a metodologia adotada foi a geração de 50 cenários para cada dado utilizado. A EPE costuma apresentar 2000 cenários de previsões do CMO nos leilões de energia nova, porém como foram testados vários tipos de dados históricos na entrada desse problema, o custo computacional de 2000 cenários seria alto, pois a rede leva de 3 a 6 minutos para ser treinada, i.e, para a geração de 2000 cenários utilizando um tipo de dado, seriam necessários 12 mil minutos, equivalente a 8 dias. Como nesse experimento serão utilizados 6 tipos de dados diferentes na entrada desse problema, seriam necessários mais de um mês para a realização desse único experimento. Logo, optou-se por reduzir o número de cenários para 50, para cada dado experimentado. Sendo assim, na próxima seção serão exemplificados os resultados através de um dos 50

cenários obtidos em cada experimento e apresentar a média de erros dos testes realizados.

Para avaliar o nível de erro obtido nesses testes, experimentou-se gerar outros 50 cenários para os 10% dos dados históricos com a função *random* do Matlab. Essa função pode ser definida pela média e pelo desvio padrão da série histórica e a partir disso gerará previsões aleatórias padronizadas por essas medidas. Também pode-se usar a função *rand*, que possibilita a inserção de limites de mínimo e máximo, para gerar previsões randômicas dentro desses limiares estabelecidos. Essas funções foram aplicadas nesse trabalho com objetivo de calcular o RMSE desses cenários aleatórios para comparar com o erro obtido nos cenários gerados pela RNR.

## 4.2 PREVISÃO DE DADOS PARA HORIZONTES LONGOS

O segundo teste realizado nesse trabalho tem o objetivo de utilizar a rede neural para gerar cenários para horizontes longos discretizados mensalmente, que sejam coerentes com as séries históricas. Como já foi abordado, esses cenários são importantes para tomadas de decisão no SEB, por isso será apresentada uma previsão com um horizonte de cinco anos para a geração eólica e outra para o PLD.

Para realizar esse experimento será utilizado o algoritmo descrito pela Figura 16, apenas configurando o tamanho do loop de previsões, que deverá realizar 60 iterações, correspondentes aos 60 meses que deverão ser previstos, i.e, cinco anos com discretização mensal. Para avaliar esse cenário gerado pela RNR, serão calculadas as medidas estatísticas da amostra prevista e comparadas com as medidas realizadas no Capítulo 3. Isso indicará se a previsão realizada está dentro do padrão esperado para cada parâmetro. Mas é importante salientar que esses resultados não precisam ser exatamente iguais, pois esses dados retratam fenômenos que podem sofrer variações ao longo dos anos.

Também será gerada uma previsão de cinco anos randômica, com as mesmas funções usadas no teste de confiabilidade. Porém ao invés de gerar um número de previsões aleatórias correspondente a 10% da série histórica, será gerada uma previsão randômica para 60 meses, que serão comparadas com a previsão obtida através da RNR.

## 5 RESULTADOS E DISCUSSÕES


### 5.1 PREVISÕES PARA A GERAÇÃO EÓLICA

Nos experimentos realizados para a geração eólica, foram utilizados na entrada da *toolbox* os 95 dados mensais do histórico da Usina Praia Formosa.

#### 5.1.1 Teste de confiabilidade para geração eólica

Para ilustrar o resultado desse teste, foi apresentado na Figura 17 um dos 50 cenários obtidos através da rede LSTM, que gerou os últimos 10% da série histórica, ou seja, obteve-se os últimos 9 dados históricos da geração eólica da Usina Praia Formosa:


Figura 17 - Resultado do teste de confiabilidade da geração eólica.



Fonte: Elaborada pela autora (2018).

Na Figura 18 pode-se comparar o erro entre os valores histórico e os previstos, através do  $RMSE = 33,03\%$ .

Figura 18 - RMSE da geração eólica.




Fonte: Elaborada pela autora (2018).

Após realizar 50 testes iguais a esse, obtém-se um RMSE médio igual 39,60% com um desvio padrão de 3,95%. O que significa que alguns cenários são mais exatos que outros, como o cenário ilustrado pela Figura 18. Mas de modo geral esse erro é tolerável, baseado na acurácia média de 55,9% obtida nos experimentos de Nelson (2017), que considerou esse resultado satisfatório para a previsão do preço das ações, usando a rede LSTM. É importante salientar que para algumas aplicações específicas pode ser necessária uma acurácia maior nos resultados.

O segundo experimento de confiabilidade foi através da geração de cenários randômicos. Como a geração eólica apresenta um padrão mensal, utilizou-se a média e o desvio padrão de cada mês para gerar previsões aleatórias para os últimos 9 meses do histórico da Usina Praia Formosa. Um dos 50 cenários randômicos pode ser visualizado na Figura 19:




Figura 19 - Resultado do teste randômico da geração eólica.



Fonte: Elaborada pela autora (2018).

Dos 50 cenários randômicos testados, alguns apresentam resultados mais próximos ao esperado, atingindo um RMSE médio igual a 33,78%, ou seja, de modo geral os cenários randômicos apresentam um erro menor do que os cenários da rede LSTM. Porém, o desvio padrão desse erro é igual a 6,47%, por isso obtém-se alguns cenários como o da Figura 19, que apresentam um comportamento mais distante do esperado para geração eólica. Nesse cenário tem-se um  $RMSE = 44\%$  (Figura 20).

Figura 20 - RMSE do teste randômico da geração eólica.




Fonte: Elaborada pela autora (2018).

Conclui-se que para geração de um único cenário, que pode ser utilizado como variável de entrada de um modelo determinístico, a acurácia e a uniformidade dos resultados da rede LSTM são superiores aos da previsão produzida de forma aleatória, que se baseia apenas nas medidas de dispersão mensais da geração eólica. Logo, para o uso de modelos determinísticos o custo computacional envolvido na utilização de uma rede LSTM pode ser viável, tornando-a relevante para estudos que envolvam a utilização desse tipo de problema.

### 5.1.2 Previsão em horizonte plurianual

O resultado da aplicação da rede LSTM nesse experimento é mostrado na Figura 21, através de um dos cenários resultantes de geração eólica para os próximos cinco anos.


Figura 21 - Previsão de geração eólica para um horizonte de 5 anos.



Fonte: Elaborada pelo autor (2018).

A qualidade desse cenário foi avaliada através da comparação com os dados históricos de geração eólica dos últimos 5 anos (Figura 22). Visualmente percebe-se que os valores previstos estão muito próximos dos valores esperados. Isso é confirmado com o cálculo da diferença  $RMSE = 22\%$ , considerada satisfatória mediante resultados encontrados na literatura.

Figura 22 - Comparação entre a previsão e dados históricos da geração eólica.



Fonte: Elaborada pela autora (2018).

No Quadro 3 são expostos os resultados estatísticos mensais da amostra resultante do cenário apresentado na Figura 21:

Quadro 3 – Resultados da geração eólica (MWmed).

Mês	Média	Variância	Desvio Padrão	Mínimo	Máximo
Jan	40,71	15,94	3,99	36,21	46,38
Fev	25,54	15,63	3,95	20,52	30,29
Mar	17,81	9,42	3,07	13,30	21,47
Abr	10,59	5,16	2,27	8,11	13,43
Mai	9,45	7,91	2,81	5,14	12,16
Jun	16,93	10,27	3,20	11,83	19,83
Jul	21,85	12,25	3,50	18,02	25,40
Ago	28,94	13,53	3,68	22,94	32,41
Set	43,89	12,89	3,59	38,81	47,79
Out	46,83	13,35	3,65	42,44	50,49
Nov	47,55	12,62	3,55	43,11	51,16
Dez	47,46	13,58	3,69	42,79	51,65
<b>Total</b>	<b>29,80</b>	<b>213,83</b>	<b>14,62</b>	<b>5,14</b>	<b>51,65</b>


Fonte: Elaborado pela autora (2018).

Observando a análise feita no Quadro 1 da página 36, verifica-se que essa previsão realizada pela rede LSTM conseguiu distinguir as gerações nas diferentes estações do ano, apresentando um aumento da média de geração eólica nos meses de inverno e primavera. Pode-se observar que o mês mais instável desse cenário é o mês de janeiro, que possui o maior desvio padrão, tanto nos dados históricos como na previsão obtida.

Portanto, conclui-se nessa etapa que esse cenário previsto pela rede LSTM apresentou medidas estatísticas próximas aos valores históricos expostos. É relevante ressaltar que nem todos os cenários apresentam os mesmos resultados obtidos no Quadro 3, pois como mostrado no teste de confiabilidade, os cenários possuem um desvio padrão considerável.

A previsão randômica para um horizonte de cinco anos apresentou o resultado da Figura 23, obtendo-se uma RMSE = 29% em relação aos últimos cinco anos da série histórica.

Figura 23 - Previsão randômica de 5 anos para eólica.



Fonte: Elaborada pela autora (2018).

Pode-se concluir que apesar da rede LSTM apresentar cenários com resultados mais uniformes e viáveis para a utilização em modelos determinísticos, o custo computacional para produzir muitos cenários, pode ser alto, dependendo do problema utilizado, para um ganho pequeno na acurácia dos resultados. Como a geração eólica apresenta um padrão mensal, utilizar as medidas de dispersão de cada mês para criar cenários randômicos pode ser mais viável que a utilização de redes LSTM, pois o custo computacional disso é extremamente menor, já que os cenários randômicos são gerados em poucos segundos. A rede LSTM poderia apresentar resultados com uma acurácia maior se na entrada do modelo outras informações, além da geração média mensal, fossem inseridas, como a velocidade do vento e a densidade de potência, podendo trazer resultados melhores em trabalhos futuros.


## 5.2 PREVISÕES PARA O PLD

Nos testes realizados para o PLD, inicialmente foram utilizados na entrada da *toolbox* 205 dados mensais, retirados do histórico da CCEE, apresentados no Capítulo 3.

### 5.2.1 Teste de confiabilidade para o PLD

Para demonstrar o resultado desse experimento, apresenta-se na Figura 24 um dos 50 cenários obtidos através da rede LSTM, que gerou os últimos 10% dos dados históricos, ou seja, os últimos 20 meses da série histórica do PLD, de janeiro de 2017 a agosto de 2018:


Figura 24 - Resultado do teste de confiabilidade para o PLD.



Fonte: Elaborada pela autora (2018).

Nesse cenário obteve-se um  $RMSE = 71,95\%$  que demonstra um erro consideravelmente alto associado a cada previsão, como pode ser observado na Figura 25:

Figura 25 - RMSE do PLD.



Fonte: Elaborada pela autora (2018).

Após realizar 50 experimentos iguais ao descrito, obteve-se uma média de RMSE igual a 178,03% com um desvio padrão de 744,48 %. O que demonstra uma grande variabilidade nos resultados dos cenários obtidos, por isso alguns cenários são melhores que outros, como o cenário ilustrado pela Figura 25. Para melhorar essa previsão, utilizou-se alguns mecanismos que pretendiam tornar os dados da amostra de entrada do PLD mais padronizada, facilitando a previsão gerada pelo algoritmo. As alterações nos dados de entrada que foram testadas são:

- a) Remoção dos outliers, limitando todos os preços ao teto máximo atual (R\$ 505,18/MWh), para reduzir as anomalias dos dados;
- b) Correção monetária dos dados históricos com base no índice IGP-M, para trazer os preços para valor presente;
- c) Utilização dos dados a partir de 2015, após a nova regulamentação dos limites de máximo e mínimo para o PLD;

d) Combinações das opções acima.

Para encontrar a melhor forma de inserir a série de dados históricos do PLD na rede neural, foi utilizada a metodologia do teste de confiabilidade, com o objetivo de obter uma média de RMSE menor que no primeiro experimento realizado. Os resultados alcançados nos 50 testes realizados para cada alteração nos dados de entrada, estão apresentados no Quadro 4:

Quadro 4 - RMSE médio obtido nos 50 experimentos de cada dado de entrada.

<b>Dados</b>	<b>Original</b>	<b>Sem outliers</b>	<b>Correção IGP-M</b>	<b>Correção IGP-M s/ outliers</b>	<b>A partir de 2015</b>
<b>Média (%)</b>	178,03	251,04	-204,74	70,79	358,69
<b>Desvio Padrão (%)</b>	744,48	386,92	2605,30	2508,77	3550,11

Fonte: Elaborado pela autora (2018).


Foi verificado através dos resultados do Quadro 4, que o alto desvio padrão desse erro indica que em geral as previsões apresentam resultados bastante distintos para cada cenário gerado. Isso ocorre pois em vários cenários a rede LSTM apresenta preços negativos, o que é intolerável para a realidade. Essa situação é verificada com mais frequência quando o neurônio de entrada é alimentado com os dados corrigidos monetariamente e quando são utilizados apenas os dados a partir de 2015. Nesse último caso, também ocorrem previsões com preços tendendo a zero, o que também implica em uma média de erros saliente. Outro problema que se repete nos cenários que utilizam a correção IGP-M, é a suposição de preços extremamente altos, acima de mil reais, o que não é plausível diante dos limites de preços atuais, gerando erros proeminentes na maioria dos cenários testados. Para corrigir essas anomalias, causadas pelos outliers, combinou-se a correção monetária com a remoção de outliers. Essa alteração fez a rede perder a sensibilidade em relação as variações voláteis de preço em vários cenários, onde obteve-se previsões de preços praticamente constante ao longo dos meses, apresentando uma média de RMSE mais baixa, porém com uma dispersão muito saliente, devido aos cenários sem coerência com a realidade da volatilidade dos preços. Logo, como esses resultados se repetiam com frequência nos cenários, essas três alterações nos dados de entrada foram descartadas.



Ao utilizar os 205 dados mensais apenas removendo os outliers, obteve-se uma média RMSE, nos 50 cenários observados, maior que a dos dados originais. Porém, através do desvio padrão menor, pode-se observar que as previsões realizadas pelos dados sem outliers são mais uniformes, apresentando cenários com menos dispersão em relação à média, quando comparado com o uso dos dados originais na entrada do algoritmo.

Por fim, foi experimentado utilizar as funções randômicas, *random* e *rand*, para tentar gerar previsões com erros menores. Como o PLD não apresentou um padrão em relação as suas medidas de dispersão mensais, a função *random*, não apresentou melhoras nos resultados, atingindo um RMSE médio = 219,75% e desvio padrão do erro = 199,06%. Além disso, esses cenários gerados randomicamente apresentavam preço negativos, um resultado inviável para esse trabalho. Optou-se por utilizar os limites de preço mínimo e máximo homologados para 2018, na geração de cenários aleatórios para os últimos 20 meses do PLD, utilizando a função *rand*. Um dos 50 cenários randômicos é ilustrado pela Figura 26:


Figura 26 - Resultado do teste randômico para o PLD.



Fonte: Elaborada pela autora (2018).

Dos 50 cenários randômicos testados, alguns apresentam resultados mais próximos ao esperado, o que resultou em um RMSE médio igual a 79,76% e desvio padrão em relação à média de erros igual a 15,35%, sendo o melhor resultado obtido no teste de confiabilidade para o PLD. O cenário da Figura 26 possui RMSE = 64,93% (Figura 27).

Figura 27 - RMSE do teste randômico do PLD.




Fonte: Elaborada pela autora (2018).

### 5.2.2 Previsão em horizonte plurianual

Utilizando a rede LSTM foi gerada a previsão do PLD para os próximos cinco anos, usando os 205 dados históricos originais. Um dos cenários observados está na Figura 28:


Figura 28 - Previsão de cinco anos para o PLD.



Fonte: Elaborada pela autora (2018).

Para verificar a efetividade desse cenário, ele foi comparado com os preços dos últimos 5 anos (Figura 29). Calculando o RMSE entre o histórico e as previsões desse cenário, foi obtido uma diferença de 67%.

Figura 29 - Comparação entre a previsão e dados históricos do PLD.



Fonte: Elaborada pela autora (2018).

No Quadro 5 são apresentadas as medidas estatísticas mensais dos resultados obtidos através da amostra da Figura 28 - Previsão de cinco anos para o PLD.Figura 28.

Quadro 5 – Resultados do PLD (R\$/MWh).

Mês	Média	Variância	Desvio Padrão	Mínimo	Máximo
Jan	245,97	32257,64	179,60	56,87	515,43
Fev	252,06	51220,57	226,32	59,88	623,87
Mar	284,63	42421,44	205,96	129,67	646,27
Abr	282,56	46818,91	216,38	104,77	648,04
Mai	327,21	46676,59	216,05	167,46	697,28
Jun	341,23	58319,78	241,49	141,44	714,26
Jul	321,08	44403,33	210,72	85,25	568,62
Ago	320,27	71580,62	267,55	34,17	694,94
Set	335,50	90145,45	300,24	7,77	748,68
Out	392,56	112810,74	335,87	8,05	862,33
Nov	398,63	91903,86	303,16	17,04	856,15
Dez	328,04	45394,49	213,06	30,75	609,51
<b>Total</b>	<b>319,15</b>	<b>51877,81</b>	<b>227,77</b>	<b>7,77</b>	<b>862,33</b>

Fonte: Elaborado pela autora (2018).

No quadro acima, pode-se observar que o a RNR foi capaz de prever preços médios maiores para os meses do período seco, como apontado pela análise feita no Quadro 2, mostrada na página 42. Porém, o desvio padrão de cada mês continua sendo elevado, trazendo imprecisão para esses resultados. Como mencionado na metodologia, as medidas estatísticas dos resultados obtidos não precisam ser idênticas aquelas obtidas nas análises do Capítulo 3, pois esses fenômenos estudados estão sujeitos a mudanças ao longo do tempo. De fato, com as mudanças na regulamentação a partir de 2015, as medidas estatísticas sofreram alterações nos últimos anos. Por isso, apresenta-se no Quadro 6 o comportamento estatístico dos últimos 3 anos, para observar as semelhanças entre o histórico recente e o resultado obtido no Quadro 5.

Quadro 6 - Medidas estatísticas a partir de 2015 (R\$/MWh).

Mês	Média	Variância	Desvio Padrão	Mínimo	Máximo
Jan	188,15	19290,18	138,89	30,25	388,48
Fev	180,95	18728,55	136,85	30,25	388,48
Mar	216,76	14773,12	121,54	30,25	388,48
Abr	225,76	26416,35	162,53	40,16	431,99
Mai	316,94	22269,75	149,23	77,64	488,22
Jun	275,20	28246,07	168,07	61,80	505,18
Jul	269,60	24613,54	156,89	76,62	505,18
Ago	320,56	39533,89	198,83	102,75	533,82
Set	307,15	26620,59	163,16	150,47	533,82
Out	304,64	22863,93	151,21	168,70	533,82
Nov	295,95	21927,49	148,08	155,42	533,82
Dez	168,26	3022,01	54,97	102,90	276,82
<b>Total</b>	254,79	24338,06	156,01	30,25	533,82

Fonte: Elaborado pela autora (2018).

No capítulo 3, como eram analisados dados desde 2001, a média mensal dificilmente chegava a R\$ 200 /MWh. Entretanto, observando os anos após a nova regulamentação, os valores mínimos e o preço médio de cada mês aumentaram, como pode ser observado no Quadro 6. De modo geral, isso também ocorre no cenário gerado pela RNR, que apresentou um aumento nas médias de preço mensais, como mostrado no Quadro 5. Portanto, o cenário obtido na Figura 28 demonstra, como Nelson (2017) afirmou, que as redes neurais recorrentes possuem inteligência para identificar mudanças recentes nos dados históricos para gerar a próxima previsão, devido sua memória de curto prazo. Mas ainda assim, não se pode garantir a exatidão das estimativas realizadas pela rede LSTM. Pois, observando os primeiros preços obtidos na Figura 28, verificam-se valores próximos de R\$ 800/MWh. O que não é coerente com os preços limites homologados nos últimos 3 anos. Ou seja, os preços que serão validados para o próximo ano podem sofrer reajustes, mas é improvável que essa revisão resulte em limites acima de R\$ 800 /MWh, baseado nos reajustes feitos desde a implantação da nova regulamentação da ANEEL. Também é importante ressaltar, que nem todos os cenários apresentam os mesmos resultados obtidos na Figura 28, pois como mostrado no teste de confiabilidade, os cenários possuem um desvio padrão relevante.

Portanto, a rede LSTM demonstra capacidade para reconhecer as novas tendências de valores dentro de uma série temporal longa. Porém, como mencionado na análise dos dados históricos, muitos fatores não-estatísticos e não-naturais influenciam na formação do preço da energia.

Essas distorções que podem ser de origem governamental ou estarem ligadas as interferências de outros mercados, não são facilmente compreendidas pela rede neural, por isso, os testes apresentam um elevado erro entre o histórico e a previsão. Logo, além do custo computacional envolvido na geração de vários cenários, as previsões não apresentam uma acurácia tolerável. Consequentemente, chutes aleatórios dentro dos limites de preço atuais, apresentam resultados mais coerentes com a realidade que a tentativa de prever o futuro do PLD com redes LSTM.

## 6 CONCLUSÃO

Esse trabalho de conclusão de curso teve como premissa estudar a geração de cenários de geração eólica e de PLD utilizando técnicas de aprendizado de máquina, através da aplicação da rede LSTM. Para direcionar os resultados esperados nos experimentos, a análise histórica indicou as tendências estatísticas de cada dado estudado, oferecendo bases comparativas para os resultados obtidos. A geração eólica apresentou um comportamento padrão ao longo dos meses, que foi compreendido pelas redes neurais e repetido nos resultados, gerando cenários com respostas análogas e apresentando um erro tolerável nos testes de treinamento da rede. Já no PLD observou-se através da série histórica, o grande número de influências que compõem a formação desse preço e que causaram instabilidades ao longo dos anos. Como resultados positivos obtidos, a rede neural aprendeu sobre a volatilidade desses preços e através da sua memória de curto prazo foi capaz de compreender as mudanças mais recentes do setor, gerando cenários para horizontes longos com medidas estatísticas similares ao histórico mais recente. Logo, verificou-se que o modelo de rede neural recorrente proposto era adequado para séries temporais longas. Porém, como pontos negativos, o nível de acerto medido no treinamento da rede foi inadequado e os cenários não apresentavam resultados semelhantes entre si, produzindo cenários incompatíveis com a realidade.

Portanto, foi concluído que para a geração de um único cenário para modelos determinísticos, a geração eólica demonstrou uma boa acurácia e uniformidade nos resultados obtidos através da rede LSTM, tornando o custo computacional envolvido nesse processo viável, o que demonstra a relevância do uso de rede neurais nos estudos que envolvem esse tipo de problema. Mas para a geração de muitos cenários, o custo computacional é elevado, podendo ser mais viável gerar cenários através de funções randômicas que utilizam medidas estatísticas, que são capazes de gerar centenas de cenários em poucos segundos com uma precisão similar ao obtido pela rede LSTM. O uso de RNRs pode apresentar resultados com uma acurácia maior em trabalhos futuros se na entrada do modelo outras informações forem inseridas. Para a geração eólica, poderiam ser fornecidas a velocidade do vento e a densidade de potência, e para o PLD a previsão de afluências e o histórico dos preços dos combustíveis, para modelar outros parâmetros que influenciam no comportamento dos dados que foram estudados nesse trabalho.





## REFERÊNCIAS

ABEEÓLICA. **InfoVento 08**. Disponível em: < [http://abeeolica.org.br/wp-content/uploads/2018/11/InfoventoPT\\_Online\\_8.pdf](http://abeeolica.org.br/wp-content/uploads/2018/11/InfoventoPT_Online_8.pdf)> Acesso em: 9 de novembro de 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **A ANEEL**. Disponível em: <<http://www.aneel.gov.br/a-aneel>> Acesso em: 13 de setembro de 2018.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Limites do PLD para 2018 são homologados**. Disponível em: <[http://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset\\_publisher/zXQREz8EVIZ6/content/limites-do-pld-para-2018-sao-homologados/656877/pop\\_up?\\_101\\_INSTANCE\\_zXQREz8EVIZ6\\_viewMode=print&\\_101\\_INSTANCE\\_zXQREz8EVIZ6\\_languageId=pt\\_BR](http://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/limites-do-pld-para-2018-sao-homologados/656877/pop_up?_101_INSTANCE_zXQREz8EVIZ6_viewMode=print&_101_INSTANCE_zXQREz8EVIZ6_languageId=pt_BR)> Acesso em: 13 de setembro de 2018.

AMARANTE, O. A. C. et al. **Atlas do Potencial Eólico Brasileiro**. Disponível em: <[http://www.cresesb.cepel.br/publicacoes/download/atlas\\_eolico/Atlas%20do%20Potencial%20Eolico%20Brasileiro.pdf](http://www.cresesb.cepel.br/publicacoes/download/atlas_eolico/Atlas%20do%20Potencial%20Eolico%20Brasileiro.pdf)> Acesso em: 9 de novembro de 2018.

ARAÚJO, Tiago A. **Técnicas de modelagem florestal empregadas na estimativa volumétrica de eucalipto**. 2016. 29 f. Pesquisa (graduação) – Universidade de Brasília, Brasília.

BARRETO, Jorge M. **Introdução às redes neurais artificiais**. Laboratório de Conexionismo e Ciência Cognitivas UFSC - Departamento de Informática e de Estatística, 2002.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Metodologia de Preços**. Disponível em: < [https://www.ccee.org.br/portal/faces/pages\\_publico/o-que-fazemos/como\\_ccee\\_atua/precos/metodologia\\_de\\_precos](https://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/precos/metodologia_de_precos)> Acesso em: 13 de setembro de 2018.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Patamares**. Disponível em: <[https://www.ccee.org.br/portal/faces/pages\\_publico/o-que-fazemos/como\\_ccee\\_atua/patamares\\_contab](https://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/patamares_contab)> Acesso em: 13 de setembro de 2018.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Preços.**

Disponível em:

<[https://www.ccee.org.br/portal/faces/oquefazemos\\_menu\\_lateral/precos](https://www.ccee.org.br/portal/faces/oquefazemos_menu_lateral/precos)>

Acesso em: 13 de setembro de 2018.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Preços em formato XLS.** Disponível em:

<[https://www.ccee.org.br/portal/faces/pages\\_publico/o-que-fazemos/como\\_ccee\\_atua/precos/precos\\_csv](https://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/precos/precos_csv)>

Acesso em: 13 de setembro de 2018.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Razão de ser.** Disponível em: <

[https://www.ccee.org.br/portal/faces/pages\\_publico/quem-somos/razao-de-ser](https://www.ccee.org.br/portal/faces/pages_publico/quem-somos/razao-de-ser)>

Acesso em: 13 de setembro de 2018.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Setor Elétrico: Entenda o modelo brasileiro.** Disponível em:

<[https://www.ccee.org.br/portal/faces/pages\\_publico/onde-atuamos/setor\\_eletrico](https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/setor_eletrico)>

Acesso em: 13 de setembro de 2018.

CASA DOS VENTOS. **Energia eólica.** Disponível em:

<<http://casadosventos.com.br/pt/energia-dos-ventos/energia-eolica>>

Acesso em: 9 de novembro de 2018.

ENEX O&M DE SISTEMAS ELÉTRICOS. **Sistema Elétrico Brasileiro:**

**Usinas Hidrelétricas.** Módulo de Treinamento e Capacitação. Florianópolis, 2012.

EMPRESA DE PESQUISA ENERGÉTICA. **Leilão de Energia Nova A-6**

**2018.** Disponível em: < <http://epe.gov.br/pt/leiloes-de-energia/leiloes/leilao-de-energia-nova-a-6-2018>> Acesso em: 30 de outubro de 2018.

FAVERA, A. C. D. et al. **Análise do comportamento estatístico anual e**

**sazonal dos ventos para a região central do Rio Grande do Sul.** 2010. 4 f.

Artigo (graduação) – Universidade Federal de Santa Maria, Santa Maria.

INSTITUTO DE ENERGIA E MEIO AMBIENTE. **Setor Elétrico Brasileiro.**

Disponível em: <<http://comunica.energiaeambiente.org.br>> Acesso em: 13 de setembro de 2018.

MATHWORKS. **Time Series Forecasting Using Deep Learning.** Disponível

em: <<https://la.mathworks.com/help/deeplearning/examples/time-series-forecasting-using-deep-learning.html>> Acesso em: 2 de outubro de 2018.

MAYON, Paulo. **Matriz e Segurança Energética Brasileira**. Disponível em: <<https://portalibre.fgv.br/data/files/B4/47/89/25/5C266410304BD3645C28C7A8/Paulo%20Mayon.pdf>> Acesso em: 12 de novembro de 2018.

NELSON, David M. Q. **Uso de redes neurais recorrentes para previsão de séries temporais financeiras**. 2017. 73 f. Dissertação (mestrado) – Universidade Federal de Minas Gerais, Belo Horizonte.

OPERADOR NACIONAL DO SISTEMA. **Histórico da operação: Geração de energia**. Disponível em: <[http://ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao\\_energia.aspx](http://ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx)> Acesso em: 2 de outubro de 2018.

OPERADOR NACIONAL DO SISTEMA. **O que é o ONS**. Disponível em: <<http://ons.org.br/paginas/sobre-o-ons/o-que-e-ons>> Acesso em: 13 de setembro de 2018.

OPERADOR NACIONAL DO SISTEMA. **O sistema interligado nacional**. Disponível em: <<http://ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>> Acesso em: 13 de setembro de 2018.

PANORAMA COMERC. **Indicadores: Nível dos reservatórios**. Disponível em: <<http://panorama.comerc.com.br/2018/01/2018-inicia-com-discreto-aumento-no-nivel-dos-reservatorios/>> Acesso em: 13 de novembro de 2018.

PORTAL BRASIL. **Índice Geral de Preços do Mercado – IGP-M**. Disponível em: <<https://www.portalbrasil.net/igpm.htm>> Acesso em: 16 de outubro de 2018.

QUIROZ, Dante E. S. **Análise comparativa de diferentes metodologias de redes neurais artificiais para previsão de geração eólica**. 2017. 145 f. Dissertação (mestrado) – Universidade Federal de Santa Catarina, Florianópolis.

SAUER, I. L. et al. **O racionamento de energia elétrica decretado em 2001: Um estudo sobre as causas e as responsabilidades**. Disponível em: <<http://www.iee.usp.br/sites/default/files/biblioteca/producao/2001/Monografia%20ILDO-Estudo%20sobre%20o%20Racionamento%2015-12-2001.PDF>> Acesso em: 12 de novembro de 2018.

SILVA, Edson L. **Formação de Preços em Mercados de Energia Elétrica**. 1. ed. Porto Alegre: Editora Sagra Luzzatto, 2001.

SILVA, J. P. M. et al. **Rede neurais artificiais para estimar volume comercial e total de Eucalyptus spp.** 2016. 4 f. Artigo (graduação) – Universidade Federal de Minas Gerais, Belo Horizonte.